

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук
(повна назва)

Кафедра Штучного інтелекту
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти другий (магістерський)

Дослідження методів визначення емоційного забарвлення текстів
(тема)

Виконав:
здобувач другого року навчання,
групи СШМ-23-2

Ігор Боков
(власне ім'я, прізвище)

Спеціальність 122 Комп'ютерні науки
(код і повна назва спеціальності)

Тип програми освітньо-наукова
(освітньо-професійна або освітньо-наукова)

Освітня програма Системи штучного інтелекту
(повна назва освітньої програми)

Керівник проф. Костянтин Петров
(посада, власне ім'я, прізвище)

Допускається до захисту

Завідувач кафедри ШІ _____
(підпис)

Олег ЗОЛОТУХІН
(власне ім'я, прізвище)

2025 р.

Харківський національний університет радіоелектроніки

Факультет _____ Комп'ютерних наук _____

Кафедра _____ Штучного інтелекту _____

Рівень вищої освіти _____ другий (магістерський) _____

Спеціальність _____ 122 Комп'ютерні науки _____
(код і повна назва)

Тип програми _____ освітньо-наукова _____
(освітньо-професійна або освітньо-наукова)

Освітня програма _____ Системи штучного інтелекту _____
(повна назва)

ЗАТВЕРДЖУЮ:
Зав. кафедри _____
(підпис)
« _____ » _____ 20 ____ р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

здобувачеві _____ Бокову Ігорю Петровичу _____
(прізвище, ім'я, по батькові)

1. Тема роботи _____ Дослідження методів визначення емоційного забарвлення текстів _____

затверджена наказом університету від 21 квітня 2025 р. № 295Ст

2. Термін подання студентом роботи до екзаменаційної комісії 6 червня 2025 р.

3. Вихідні дані до роботи _____ Науково-технічні публікації, дані з відкритих джерел, Python documentation, набір даних для тренування та тестування комбінованого методу _____

4. Перелік питань, що потрібно опрацювати в роботі _____

1) Аналіз предметної галузі _____

2) Порівняльний аналіз існуючих методів емоційного аналізу текстів _____

3) Розробка комбінованого методу аналізу тональності текстів _____

4) Експериментальна перевірка працездатності розробленого методу _____

5) Аналіз результатів дослідження і формулювання рекомендацій з використання методу _____

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Строк / терміни виконання етапів роботи	Примітка
1	Отримання завдання на кваліфікаційну роботу	21.04.2025	виконано
2	Аналіз предметної галузі	23.04.2025	виконано
3	Огляд методів визначення емоційного забарвлення текстів	27.04.2025	виконано
4	Постановка задачі дослідження та вибір оптимальних методів аналізу	02.05.2025	виконано
5	Розробка комбінованого методу визначення емоційного забарвлення тексту	07.05.2025	виконано
6	Написання пояснювальної записки	12.05.2025	виконано
7	Перевірка на академічний плагіат	15.05.2025	виконано
8	Нормоконтроль	18.05.2025	виконано
9	Підготовка презентації та доповіді	25.05.2025	виконано
10	Попередній захист	01.06.2025	виконано
11	Рецензування	02.06.2025	виконано
12	Захист перед ЕК	06.06.2025	

Дата видачі завдання 21 квітня 2025 р.

Здобувач _____

Боків
(підпис)

Керівник роботи _____

Костянтин
(підпис)

проф. Костянтин Петров _____

(посада, власне ім'я, прізвище)

РЕФЕРАТ

Пояснювальна записка: 64 с., 8 рис., 9 табл., 1 дод., 23 джерела.

ГЛИБОКА НЕЙРОННА МЕРЕЖА, ЕМОЦІЙНА ТОНАЛЬНІСТЬ,
ЛІНГВІСТИЧНИЙ АНАЛІЗ, МАШИННЕ НАВЧАННЯ,
ПРИРОДНОМОВНИЙ ТЕКСТ.

Об'єкт дослідження – процес автоматизованого інтелектуального аналізу природномовної текстової інформації.

Предмет дослідження – методи та моделі машинного навчання, що використовуються для автоматичного визначення емоційного забарвлення тексту.

Мета роботи – аналіз та порівняння новітніх методів аналізу емоційної тональності природномовних текстів та розробка власного комбінованого методу визначення емоційного забарвлення тексту для підвищення точності такого аналізу.

Методи дослідження – системний аналіз задач інтелектуального аналізу природномовної текстової інформації, методи машинного навчання, апарат штучних нейронних мереж, методи розв'язання задачі визначення емоційного забарвлення тексту, а також методи математичного та комп'ютерного моделювання, що застосовані для верифікації точності та оцінки ефективності запропонованого підходу.

Головним результатом роботи є розробка комбінованого методу визначення емоційного забарвлення тексту, що поєднує лексичний аналіз та глибоке навчання на основі трансформерів.

Використання методу дозволить більш ефективно аналізувати контекст і складні мовні конструкції, що робить його перспективним для аналізу громадської думки в соціальних мережах та чат-ботах.

ABSTRACT

Master's thesis contains: 64 pp., 8 fig., 9 tabl., 1 ann., 23 references.

DEEP NEURAL NETWORK, EMOTIONAL TONALITY, LINGUISTIC ANALYSIS, MACHINE LEARNING, NATURAL LANGUAGE TEXT.

Object of the research is the process of automated intelligent analysis of natural language textual information.

Subject of the research is machine learning methods and models used for automatic detection of the emotional tone of texts.

Purpose of the work is to analyze and compare modern methods for detecting emotional tonality in natural language texts and to develop a custom combined method for determining emotional tone to improve the accuracy of such analysis.

Research methods include system analysis of the tasks of intelligent processing of natural language textual data, machine learning methods, artificial neural network tools, methods for solving the problem of emotional tone detection, as well as mathematical and computer modeling methods used to verify the accuracy and evaluate the efficiency of the proposed approach.

The main result of the work is the development of a combined method for detecting emotional tone in texts that integrates lexical analysis and deep learning based on transformer architectures.

The application of this method enables more effective analysis of context and complex linguistic structures, making it promising for public opinion analysis in social networks and chatbot applications.

ЗМІСТ

Скорочення та умовні позначки	7
Вступ	8
1 Аналіз предметної галузі та постановка задачі дослідження	10
1.1 Поняття емоцій та їх класифікація у текстах	10
1.2 Лінгвістичні та психологічні аспекти визначення емоцій у текстах ..	12
1.3 Методи аналізу текстів у контексті обробки природної мови	14
1.3.1 Лексиконні методи	14
1.3.2 Статистичні методи	16
1.3.3 Методи на основі алгоритмів машинного навчання.....	17
1.3.4 Гібридні методи	20
1.4 Постановка задачі дослідження.....	22
2 Методи та алгоритми аналізу емоційного забарвлення текстів	23
2.1 Лексичні методи	23
2.2 Статистичні методи та класичне машинне навчання	30
2.3 Методи глибокого навчання	36
3 Розробка комбінованого методу аналізу тональності текстів	42
3.1 Архітектура методу	42
3.2 Інструменти та параметри реалізації.....	46
4 Експериментальна перевірка ефективності комбінованого методу	51
4.1 Опис умов проведення експерименту	51
4.2 Оцінка отриманих результатів.....	56
Висновки.....	59
Перелік джерел посилання	62
Додаток А Відомість кваліфікаційної роботи	64

СКОРОЧЕННЯ ТА УМОВНІ ПОЗНАКИ

BERT – Bidirectional Encoder Representations from Transformers – двонапрямні подання на основі трансформерів;

CNN – Convolutional Neural Networks – згорткові нейронні мережі;

GRU – Gated Recurrent Unit – рекурентний блок із механізмами затворів;

k-NN – k-Nearest Neighbors – метод k-найближчих сусідів;

LIWC – Linguistic Inquiry and Word Count – лінгвістичний аналіз і підрахунок слів;

LSA – Latent Semantic Analysis – латентно-семантичний аналіз;

LSTM – Long Short-Term Memory – довга короткочасна пам'ять;

NLP – Natural Language Processing – обробка природної мови;

RNN – Recurrent Neural Networks – рекурентні нейронні мережі;

SVM – Support Vector Machines – машина опорних векторів;

TF-IDF – Term Frequency-Inverse Document Frequency – частота слова-зворотна частота документа;

VADER – Valence Aware Dictionary and sEntiment Reasoner – словник й оцінювач тональності з урахуванням валентності.

ВСТУП

Визначення емоційного забарвлення тексту є однією з ключових задач обробки природної мови (NLP) та відіграє важливу роль у численних прикладних сферах, зокрема в маркетингу, соціології, психології, аналізі громадської думки та інформаційній безпеці. Суттєве зростання обсягу текстових даних у соціальних мережах, новинних ресурсах, блогах, коментарях та на форумах значно посилює потребу в автоматичному визначенні тональності [1]. Системи аналізу тональності тексту дозволяють оперативно отримувати структуровану інформацію про емоційні настрої суспільства, прогнозувати реакцію на певні події, виявляти потенційні загрози чи деструктивний контент, а також здійснювати моніторинг громадської думки в реальному часі.

Попри значні успіхи в цій сфері, існуючі методи аналізу тональності мають ряд обмежень, які знижують їх ефективність. Зокрема, традиційні підходи, такі як методи на основі словників чи статистичного аналізу, часто не враховують контекстуального значення слів, що є критично важливим для точного розпізнавання емоційного забарвлення [2]. Крім того, багато алгоритмів стикаються з труднощами при аналізі багатозначних слів, сарказму, іронії, неформальних та сленгових виразів, які досить часто використовуються в сучасній комунікації. Ці нюанси роблять аналіз текстів більш складним завданням та потребують більш глибокого розуміння контексту й лінгвістичних особливостей мови. Ще однією важливою проблемою є відсутність достатньої кількості маркованих даних, що ускладнює навчання точних і надійних моделей. Крім того, тексти, що містять змішані емоції чи неоднозначні почуття, також є важкими для їх коректної класифікації за допомогою стандартних алгоритмів, які часто орієнтовані на чітко виражені емоції [1]. Для подолання цих проблем необхідно розробляти та застосовувати гібридні підходи, які б ефективно поєднували переваги кількох алгоритмічних рішень.

Таким чином, існує потреба у подальшому вдосконаленні методів аналізу тональності тексту шляхом інтеграції різних підходів, зокрема з використанням сучасних моделей глибокого навчання, таких як нейронні мережі з увагою (attention mechanisms), трансформерні моделі (наприклад, BERT, RoBERTa, GPT), що дозволяють краще враховувати контекстуальні та семантичні особливості текстів [3], [4]. Використання трансформерних моделей, які засновані на самонавчанні без вчителя (self-supervised learning), забезпечує глибше розуміння контексту через можливість моделювати семантичні взаємозв'язки між словами на різних відстанях у тексті. Водночас, поєднання нейронних мереж із механізмами уваги дозволяє акцентувати увагу моделі на найбільш значущих елементах тексту, підвищуючи точність і чутливість аналізу [5]. Важливим напрямом також є дослідження та впровадження мультимодальних підходів, які поєднують аналіз тексту з аудіо- чи відеоінформацією для забезпечення більш комплексного розуміння емоційного стану та настроїв людей.

Метою роботи є детальний аналіз та порівняння новітніх методів аналізу емоційної тональності природномовних текстів, виявлення їх сильних та слабких сторін, а також розробка власного комбінованого методу, який би забезпечив підвищення точності визначення емоційного забарвлення за рахунок ефективного поєднання різних підходів і передових моделей машинного навчання.

Результати дослідження можуть бути використані для вдосконалення автоматизованих систем аналізу текстових даних у маркетингу, соціальних мережах та службах підтримки клієнтів; покращення методів фільтрації контенту в соціальних мережах і автоматизованого моделювання емоцій користувачів; розробки більш ефективних інструментів аналізу текстів у психологічних та соціологічних дослідженнях, а також для подальшого розвитку методів штучного інтелекту в галузі обробки природної мови.

1 АНАЛІЗ ПРЕДМЕТНОЇ ГАЛУЗІ ТА ПОСТАНОВКА ЗАДАЧІ ДОСЛІДЖЕННЯ

1.1 Поняття емоцій та їх класифікація у текстах

Емоції є невід'ємною частиною людського спілкування та відіграють ключову роль у вираженні суб'єктивного ставлення людей до подій, явищ і предметів навколишнього світу. Аналіз емоцій дозволяє автоматично ідентифікувати емоційний стан автора тексту, що має важливе значення в таких сферах, як маркетинг, соціологія, психологія, моніторинг ЗМІ, політичний аналіз та автоматизоване обслуговування клієнтів.

Виявлення емоцій у тексті є складною задачею, оскільки вона ускладнюється особливостями контексту, багатозначністю мови, наявністю стилістичних засобів, таких як сарказм, іронія чи метафори. Через це для класифікації емоцій у текстах використовуються різноманітні підходи та методології.

Один з найпоширеніших підходів – це класифікація за полярністю емоцій, що передбачає поділ текстів на три основні категорії: позитивні, негативні та нейтральні. Позитивні емоції включають такі почуття, як радість, задоволення, захоплення, надія та вдячність. До негативних емоцій належать смуток, гнів, страх, розчарування, тривога. Нейтральні емоції характеризуються відсутністю яскраво вираженого емоційного забарвлення або збалансованим і об'єктивним ставленням до предмета чи події.

Інший популярний підхід базується на теорії базових емоцій, розробленій американським психологом Полом Екманом [6]. Ця теорія виділяє шість універсальних базових емоцій: радість, смуток, гнів, страх, здивування та огиду. Завдяки своїй універсальності ця модель широко використовується у міжкультурних дослідженнях і стала фундаментом для створення багатьох автоматизованих систем аналізу емоцій.

Подальшим розвитком концепції базових емоцій стала модель «Колесо емоцій» (“Wheel of Emotions”), запропонована Робертом Плутчиком [7]. Вона охоплює вісім основних емоцій: радість, довіру, страх, здивування, сум, відразу, гнів та очікування. Ці емоції можуть комбінуватись між собою, формуючи більш складні та тонкі емоційні стани, наприклад, любов (поєднання радості та довіри) або тривога (поєднання страху й очікування).

Окремим підходом є континуальна класифікація емоцій, яка використовує багатовимірні простори для опису емоційних станів. Однією з найпоширеніших є тривимірна модель, що описує емоції через три параметри: валентність (ступінь позитивності чи негативності емоції), активацію (від стану спокою до інтенсивного збудження) і домінантність (ступінь контролю над ситуацією) [2]. Наприклад, щастя характеризується високою валентністю, високою активацією та значною домінантністю, тоді як смуток – низькою валентністю, низькою активацією та домінантністю.

У галузі автоматичного аналізу емоцій у текстах використовуються різноманітні методи. Лексикологічні підходи застосовують спеціальні словники (наприклад, SentiWordNet, AFINN, NRC Emotion Lexicon), що містять слова з попередньо визначеним емоційним забарвленням [1], [8]. Проте суттєвим недоліком цього методу є складність врахування контексту, багатозначності слів та стилістичних особливостей текстів.

Більш точні результати демонструють методи машинного навчання, такі як наївний Байєс, машини опорних векторів (SVM) та логістична регресія, які навчаються на великих анотованих вибірках текстів [3], [9]. Останнім часом найбільш перспективними стали підходи глибокого навчання, зокрема рекурентні нейронні мережі (RNN), мережі довгої короткострокової пам'яті (LSTM) та трансформери (BERT, GPT) [4]. Вони враховують контекст і семантичні зв'язки між словами, а також можуть інтерпретувати складні стилістичні прийоми, такі як іронія та сарказм.

Таким чином, аналіз емоцій у текстах є комплексною та багатогранною задачею, що включає широкий спектр підходів і моделей – від найпростіших полярних класифікацій до складних багатовимірних моделей. Розвиток сучасних алгоритмів машинного та глибокого навчання значно покращив точність автоматичного розпізнавання емоцій у текстах, що відкриває нові можливості для досліджень у різних сферах і дозволяє створювати ефективні системи моніторингу настроїв суспільства, аналізу соціальних мереж, персоналізованої взаємодії з клієнтами та прогнозування суспільних трендів.

1.2 Лінгвістичні та психологічні аспекти визначення емоцій у текстах

Виявлення емоцій у текстах базується на двох ключових аспектах: лінгвістичному та психологічному. Лінгвістичний аспект передбачає аналіз мовних засобів, які використовуються авторами для вираження емоцій, зокрема лексики, морфології, синтаксису та стилістичних особливостей тексту [10]. Психологічний аспект акцентує увагу на емоціях як когнітивно-емоційних станах, що відображають внутрішній досвід автора, проявляючись через специфічні експресивні засоби у тексті [11].

На лексичному рівні емоції найчіткіше виражаються через використання слів та виразів із явним емоційним забарвленням. До таких слів належать «щастя», «радість», «натхнення» для позитивних емоцій, і «смуток», «гнів», «розчарування» для негативних. Крім слів з прямим емоційним значенням, існують також слова з конотативним забарвленням, емоційний вплив яких значною мірою залежить від контексту їхнього вживання.

На морфологічному рівні для підсилення емоційної насиченості тексту використовуються зменшувально-пестливі форми («маленький», «гарненький»), грубі чи вульгарні вирази, вигуки («Ох!», «Ах!», «Ого!»), а також емоційно забарвлені частки («та», «ж», «ну», «ось»).

На синтаксичному рівні для вираження емоцій часто застосовуються специфічні структури, такі як риторичні запитання («Хіба це можливо?»), окличні речення («Неймовірно!»), повтори для посилення значення («Це неможливо! Просто неможливо!»), еліпсиси (незакінчені речення) та нестандартний порядок слів, що додають тексту експресивності й напруження.

На стилістичному рівні авторами активно використовуються метафори («серце розривається від горя»), перебільшення («море сліз»), порівняння («сумний, як ніч») та пейоративні вирази («нікчемний», «жалюгідний»). Ці стилістичні прийоми дозволяють глибше та більш яскраво передати емоційні стани, викликаючи у читача певні почуття та переживання.

Психологічний аспект передбачає моделювання емоційних станів на основі психологічних теорій. Найбільш відомою є модель базових емоцій Пола Екмана [6], яка визначає шість універсальних емоцій, характерних для всіх культур: радість, смуток, гнів, страх, здивування та огиду. Ці емоції можуть комбінуватись для створення більш складних і тонких емоційних станів.

Іншою популярною психологічною моделлю є двовимірна модель Рассела, що представляє емоції через валентність і активацію. Валентність показує, чи є емоція позитивною чи негативною, тоді як активація характеризує ступінь емоційного збудження – від повного спокою до сильного емоційного піднесення [2], [7].

Крім того, важливим психологічним підходом є концепція когнітивної оцінки, згідно з якою емоційні реакції людини на текст залежать від її минулого досвіду, поточного контексту та індивідуальних особливостей особистості. Тому одні й ті ж самі слова та вирази можуть викликати різні емоційні реакції у різних читачів, що суттєво ускладнює автоматичне визначення емоцій у текстах.

Сучасні підходи до аналізу емоцій у текстах намагаються інтегрувати лінгвістичні та психологічні аспекти, створюючи комплексні моделі. Ці моделі здебільшого використовують машинне навчання та нейронні мережі, що дозволяє враховувати як лексичні особливості слів, так і контекстуальні та психологічні аспекти текстів. Такий інтегрований підхід суттєво покращує точність автоматичного аналізу емоцій, роблячи можливим його застосування у різноманітних сферах: аналізі соціальних мереж, розробці чат-ботів з емоційним інтелектом, створенні персоналізованих інтерфейсів та прогнозуванні суспільних трендів.

1.3 Методи аналізу текстів у контексті обробки природної мови

Обробка природної мови є важливим напрямом досліджень, що стосуються аналізу текстової інформації, зокрема визначення її емоційного забарвлення. У межах NLP існує широкий набір методів аналізу тексту, які можна умовно розділити на лексиконні, статистичні, методи машинного навчання та гібридні методи.

1.3.1 Лексиконні методи

Лексиконні підходи використовують словники, що містять слова або вирази з певною емоційною оцінкою [1], [8].

Розглянемо їх більш детально.

Сентиментні лексикони – спеціально сформовані переліки слів із визначеною емоційною характеристикою (позитивна, негативна чи нейтральна). Наприклад, до таких ресурсів належать WordNet-Affect, SentiWordNet, LIWC (Linguistic Inquiry and Word Count).

Розширені лексикони – бази даних, які окрім емоційних слів, включають також їхні синоніми, антоніми та оцінку інтенсивності емоцій.

Одним із прикладів є VADER (Valence Aware Dictionary and sEntiment Reasoner), який особливо підходить для аналізу текстів із соціальних мереж.

Методи на основі правил (Rule-based methods) – ґрунтуються на використанні наборів правил, що дозволяють враховувати контекст для посилення чи зменшення емоційного забарвлення фраз (наприклад, різниця між «дуже щасливий» і «трохи щасливий»).

У таблиці 1.1 подано порівняння лексиконних методів аналізу текстів.

Таблиця 1.1 – Лексиконні методи аналізу текстів

Метод	Опис	Переваги	Недоліки
Сентиментні лексикони (WordNet-Affect, SentiWordNet, LIWC)	Застосування попередньо підготовлених словників, що містять слова з визначеною емоційною оцінкою.	Простота реалізації; не потребує навчання моделі.	Не враховує контекст; обмежений наявною лексичною базою.
Розширені лексикони (наприклад, VADER)	Словники, адаптовані для аналізу специфічних типів текстів, таких як публікації в соціальних мережах.	Ефективні для коротких текстів; зручні для обробки неформального мовлення.	Недостатньо чутливі до сарказму; можуть не враховувати складні граматичні конструкції.
Методи на основі правил	Аналіз емоційного забарвлення на основі заздалегідь визначених граматичних та логічних правил.	Гнучкість; можливість адаптації до різних мов і стилістичних особливостей.	Потребують великої кількості правил; складні для масштабування.

Лексиконні підходи добре підходять для вирішення базових завдань аналізу тональності, однак їхня обмеженість проявляється у неврахуванні контексту та багатозначності слів, що негативно впливає на точність результатів.

1.3.2 Статистичні методи

Статистичні підходи ґрунтуються на аналізі частоти вживання слів, виявленні співвідношення емоційно забарвленої лексики та дослідженні словосполучень (колокацій), які часто зустрічаються разом у тексті [12].

Розглянемо їх більш детально.

TF-IDF (Term Frequency–Inverse Document Frequency) – метод, який визначає важливість слова в окремому тексті з урахуванням його загальної частотності в усьому корпусі документів. Це дозволяє виокремити значущі терміни для подальшого аналізу.

Аналіз N-грам – використовується для виявлення послідовностей слів, що можуть нести емоційне забарвлення. Наприклад, біграми на кшталт «дуже радісний» або тріграмами типу «не зовсім щасливий» можна точніше передати контекстну тональність тексту.

Latent Semantic Analysis (LSA) – статистичний метод, що виявляє приховані семантичні зв'язки між словами та документами. Завдяки зменшенню розмірності (наприклад, через сингулярне розкладання матриці термінів) LSA дозволяє моделювати семантичну подібність, що допомагає краще зрозуміти значення слів у контексті.

Кожен із розглянутих статистичних методів має свої переваги й обмеження. TF-IDF дозволяє виокремити ключові слова, але не враховує порядок і контекст. N-грамний аналіз краще відображає локальний контекст, проте зі збільшенням N зростає обчислювальна складність. LSA виявляє приховані семантичні зв'язки, однак потребує великого обсягу даних. Порівняльну характеристику цих методів представлено в таблиці 1.2.

Таблиця 1.2 – Статистичні методи аналізу текстів

Метод	Опис	Переваги	Недоліки
TF-IDF (Term Frequency–Inverse Document Frequency)	Оцінює значущість термінів у документі на основі їхньої частоти та поширеності в корпусі.	Простий у реалізації; дозволяє виокремити ключові слова.	Не враховує порядок слів; ігнорує контекст.
Аналіз N-грам	Досліджує послідовності з N слів для врахування локального контексту у тексті.	Покращує врахування контекстуальних зв'язків між словами.	Зі збільшенням значення N зростає складність обчислень.
Latent Semantic Analysis (LSA)	Виявляє приховані семантичні зв'язки між словами і документами через матричне розкладання.	Дозволяє зменшити розмірність; виявляє глибинні зв'язки.	Вимагає великого обсягу текстових даних для досягнення точності.

Застосування статистичних методів є ефективним для великих корпусів тексту, але вони також не враховують глибокий контекст слів та їхнього емоційного змісту.

1.3.3 Методи на основі алгоритмів машинного навчання

Сучасні методи визначення емоційного забарвлення текстів базуються на машинному навчанні та глибоких нейронних мережах.

Основні підходи включають: класичні алгоритми машинного навчання, векторні представлення слів (word embeddings), а також нейронні мережі, зокрема трансформерні моделі.

Розглянемо класичні алгоритми машинного навчання [13].

Naïve Bayes Classifier – ймовірнісний метод, ефективний для базових задач сентимент-аналізу.

Support Vector Machines (SVM) – добре працює з векторними представленнями слів у задачах класифікації.

Random Forest – ансамблевий підхід, придатний для багатокласової класифікації емоцій.

Розглянемо підходи, що використовують векторне представлення слів (Word Embeddings) [14].

Word2Vec, GloVe, FastText – створюють статичні вектори слів на основі їхнього контексту у великому корпусі.

Контекстуальні embeddings (наприклад, BERT) – формуються динамічно в залежності від контексту слова у реченні.

Розглянемо основні архітектури нейронних мереж, що використовуються для інтелектуального аналізу текстів [3], [15], [16], [17].

RNN, LSTM – послідовні моделі нейронних мереж, що враховують попередній контекст у тексті.

CNN – нейромережі, які аналізують текст як набір ознак, ефективні для виявлення локальних шаблонів.

Transformers (BERT, GPT, RoBERTa тощо) – потужні моделі, що працюють із контекстом всього речення одночасно.

Кожен із наведених підходів має свої особливості застосування, сильні сторони та певні обмеження, які варто враховувати при виборі оптимального методу для аналізу емоційного забарвлення текстів. Класичні алгоритми відзначаються простотою реалізації та ефективністю на невеликих обсягах даних, тоді як нейронні мережі та трансформерні моделі демонструють високу точність, але потребують значних обчислювальних

ресурсів. Для наочного порівняння основних методів машинного навчання, їхніх переваг і недоліків, наведено узагальнення у таблиці 1.3.

Таблиця 1.3 – Методи машинного навчання для аналізу текстів

Метод	Опис	Переваги	Недоліки
Naïve Bayes	Ймовірнісний класифікатор, який оцінює вірогідність приналежності тексту до певної емоційної категорії.	Простий у реалізації; ефективний на малих наборах даних.	Ігнорує залежності між словами; обмежений при складному контексті.
Support Vector Machines (SVM)	Метод класифікації, який розділяє дані за допомогою гіперплощини у векторному просторі.	Висока точність; добре працює з розрідженими даними.	Вимагає налаштування ядра; може бути неефективним на великих обсягах тексту.
Random Forest	Ансамблевий метод, що поєднує декілька дерев рішень для покращення точності класифікації.	Стійкий до перенавчання; підтримує багатокласову класифікацію.	Менш інтерпретований; вимагає більше ресурсів.
RNN / LSTM	Нейронні мережі для послідовної обробки тексту з урахуванням попереднього контексту.	Добре враховують порядок слів; придатні для обробки послідовностей.	Погано працюють із довгими залежностями; тривале навчання.

Продовження таблиці 1.3

CNN	Обробляє текст як матрицю ознак, виявляючи локальні шаблони в послідовностях слів.	Швидке навчання; ефективно в поєднанні з embeddings.	Обмежене у врахуванні глобального контексту.
Transformers (BERT, GPT, RoBERTa тощо)	Глибокі моделі, що використовують механізм self-attention для контекстного аналізу всієї послідовності.	Найвища точність; враховують складні контекстуальні зв'язки.	Потребують великих обчислювальних ресурсів; складність у навчанні.

Методи машинного навчання забезпечують високу точність аналізу емоційного забарвлення текстів, проте вони потребують великих обсягів даних для навчання та складних обчислювальних ресурсів.

1.3.4 Гібридні методи

Для підвищення точності аналізу сучасні системи визначення емоційного забарвлення текстів використовують комбіновані підходи, що поєднують лексиконні методи, статистичний аналіз та глибокі нейронні мережі. Наприклад, спочатку може виконуватися попередній аналіз тексту за допомогою лексиконних методів, а потім отримані дані подаються на вхід глибокої нейронної мережі для уточнення емоційного забарвлення.

Такі гібридні моделі дозволяють враховувати як поверхневі лексичні ознаки, так і глибокі семантичні зв'язки у тексті. Застосування декількох підходів у межах однієї системи сприяє підвищенню загальної точності,

однак також супроводжується ускладненням реалізації та зростанням вимог до обчислювальних ресурсів. Основні типи гібридних рішень наведено в таблиці 1.4.

Таблиця 1.4 – Гібридні підходи до аналізу текстів

Метод	Опис	Переваги	Недоліки
Комбінація лексиконних та статистичних методів	Поєднання словникового аналізу з методами TF-IDF для точнішого виявлення емоцій.	Підвищення точності при збереженні простоти реалізації.	Обмежене врахування складних контекстуальних залежностей.
Поєднання класичних ML-алгоритмів та нейронних мереж	Використання SVM або Naïve Bayes у поєднанні з векторними представленнями слів (Word2Vec, GloVe).	Краща здатність розпізнавати емоційні відтінки; вища точність.	Потребує більше обчислювальних ресурсів.
Глибокі нейронні мережі з embeddings (LSTM + Word Embeddings)	Використання векторних уявлень слів у рекурентних мережах для глибокого розуміння контексту.	Висока точність; ефективно врахування контексту.	Високі обчислювальні витрати; складність реалізації.

Таким чином, аналіз текстів у контексті обробки природної мови є складним багаторівневим процесом, що поєднує лінгвістичні, статистичні та глибокі нейромереві підходи. Використання сучасних технологій машинного навчання дозволяє не лише класифікувати текст за емоційним забарвленням, але й адаптувати аналіз до конкретних мовних особливостей

та контексту, що має велике значення для автоматизованих систем аналізу текстів у соціальних мережах, журналістиці, маркетингу та інших сферах.

1.4 Постановка задачі дослідження

Метою дослідження є аналіз та порівняння новітніх методів аналізу емоційної тональності природномовних текстів та розробка власного комбінованого методу визначення емоційного забарвлення тексту для підвищення точності такого аналізу.

Для досягнення поставленої мети необхідно вирішити такі основні завдання:

- провести аналіз предметної галузі;
- дослідити існуючі методи аналізу емоційного забарвлення текстових даних та провести їх порівняння;
- розробити та описати власний комбінований метод для розв’язання задачі визначення емоційного забарвлення тексту;
- провести експериментальну перевірку працездатності та ефективності запропонованого методу;
- проаналізувати отримані результати та сформулювати рекомендації щодо підвищення точності аналізу емоційної тональності природномовних текстів.

Основну увагу в роботі буде приділено аналізу сучасних методів та моделей, що використовуються для визначення емоційного забарвлення текстової інформації з точки зору ефективності та стійкості до мовних особливостей; порівняльному аналізу традиційних лексичних підходів та методів глибокого навчання; розробці власного комбінованого підходу до визначення емоційного забарвлення тексту, а також виробленню рекомендацій щодо підвищення точності аналізу текстової тональності з точки зору контекстної семантики.

2 МЕТОДИ ТА АЛГОРИТМИ АНАЛІЗУ ЕМОЦІЙНОГО ЗАБАРВЛЕННЯ ТЕКСТІВ

2.1 Лексичні методи

Лексичні підходи до аналізу емоційної тональності тексту посідають ключове місце серед традиційних методів обробки природної мови. Вони засновані на гіпотезі, що емоційний стан автора можна визначити через використані ним мовні одиниці – переважно слова, що мають певне емоційне навантаження [15]. У центрі цих методів знаходяться так звані лексикони – попередньо сформовані списки слів, кожне з яких має заздалегідь визначену емоційну категорію або числову оцінку полярності (від сильно негативної до сильно позитивної). Залежно від типу лексикону, емоційні характеристики можуть бути представлені у вигляді бінарної шкали (позитивне або негативне), багаторівневої числової шкали (наприклад, від -5 до +5), або через категоріальну приналежність до базових емоцій за теоріями Плутчика, Екмана та інших [18], [19].

У рамках лексичного аналізу текст зазвичай проходить стандартну обробку: нормалізацію (наприклад, приведення до нижнього регістру), токенізацію (розбиття на окремі слова або фрази), лематизацію або стемінг (виділення базової форми слова). Після цього кожна лексема перевіряється на наявність у лексиконі. Якщо відповідність знайдено, відповідна емоційна вага враховується під час обчислення загальної тональності [12]. Отриманий результат може бути представлений як індекс настрою (наприклад, від -1 до +1), як вектор із кількома емоційними складовими (наприклад, відсоток позитивних, негативних і нейтральних слів), або як категорія (наприклад, «радісний», «нейтральний», «агресивний»). Структурну схему основних етапів аналізу емоційної тональності за лексичним методом наведено на рисунку 2.1.



Рисунок 2.1 – Алгоритм аналізу тексту з використанням лексичних методів

У своїй суті, лексичні методи базуються на статистичному підході до аналізу мови. Частотність емоційно забарвлених слів у тексті є вирішальним фактором для формування висновків про емоційний стан автора або тональність повідомлення [1]. Таким чином, ключова ідея полягає у підрахунку кількості позитивних, негативних або нейтральних слів та в аналізі їх сукупного впливу на загальну емоційну спрямованість тексту. Наприклад, текст із десятима позитивними словами та двома негативними може бути класифікований як позитивний з певним ступенем впевненості.

Підходи цього типу мають кілька варіацій. У найпростіших реалізаціях ваги всіх емоційних слів вважаються однаковими, однак сучасніші методи враховують інтенсивність емоційного впливу кожного слова, наприклад, слово «жахливо» може мати сильнішу негативну вагу, ніж «незадовільно» [13], [15]. Крім того, у деяких реалізаціях додатково береться до уваги граматичне заперечення (наприклад, «не добрий»), модифікатори сили, що уточнюють ступінь емоційного забарвлення висловлювання (наприклад, «дуже приємний»), та пунктуація (наприклад, наявність знаків оклику чи капс-лок як індикатор посилення емоційності).

Сучасні дослідження прагнуть удосконалити лексичні підходи шляхом поєднання їх із контекстно-залежними методами (наприклад, з використанням word embeddings або трансформерних моделей), автоматизованого розширення словників за допомогою неструктурованих корпусів та перенавчання існуючих лексиконів під специфіку конкретних мовних доменів. Попри появу новітніх глибинних моделей, лексичні методи залишаються актуальними – передусім як базовий рівень попередньої обробки, як модуль пояснюваності або як джерело ознак у складніших гібридних архітектурах.

Серед найбільш поширених лексичних ресурсів, що застосовуються в задачах аналізу емоційної тональності текстів, можна виділити такі: SentiWordNet, LIWC (Linguistic Inquiry and Word Count), AFINN та NRC Emotion Lexicon. Усі ці лексикони були створені на основі ґрунтовних лінгвістичних та психолінгвістичних досліджень, а також із залученням експертних оцінок та, у деяких випадках, автоматичних методів обробки великих корпусів текстів [1], [8].

SentiWordNet – це розширення відомої англomовної онтології WordNet, яке асоціює кожен синонімічний ряд (synset) з трьома числовими показниками: позитивністю, негативністю та нейтральністю. Цей лексикон дозволяє враховувати багатозначність слів, оскільки кожне слово в ньому розглядається в контексті свого можливого значення.

LIWC є комерційним продуктом, що має розгалужену структуру категорій – від базових емоцій до складніших психосоціальних характеристик (наприклад, «гнів», «занепокоєння», «впевненість», «особистісна референтність»). Основна перевага цього лексикону полягає у багатовимірному описі мовлення з точки зору психології, що робить його затребуваним у соціальних та поведінкових науках.

AFINN, навпаки, є прикладом лаконічного ресурсу, де кожному слову присвоєно полярну оцінку в діапазоні від -5 (максимально негативне) до +5 (максимально позитивне). Завдяки своїй простоті AFINN набув

широкого застосування в задачах, що вимагають високої швидкості обробки.

NRC Emotion Lexicon було створено на базі анотацій, здійснених великою кількістю людей через платформу Amazon Mechanical Turk. Цей лексикон асоціює слова з вісімкою основних емоцій (згідно з теорією Плутчика): радість, довіра, страх, здивування, сум, огиду, гнів, очікування. Завдяки багатій емоційній палітрі NRC активно використовується для побудови емоційних профілів текстів.

Для більш повного уявлення про особливості використання основних лексичних ресурсів доцільно порівняти їх за ключовими параметрами, такими як тип емоційної класифікації, формат оцінки, а також переваги й обмеження. У таблиці 2.1 наведено узагальнену характеристику чотирьох найбільш відомих лексиконів, які широко застосовуються у практиці аналізу емоційного забарвлення текстів у різних доменах – від соціальних мереж до психолінгвістичних досліджень.

Таблиця 2.1 – Основні характеристики лексиконів для емоційного аналізу текстів

Лексикон	Тип емоцій / Оцінка	Переваги та обмеження
AFINN	Полярність (цілі числа від -5 до +5)	Простий у реалізації, швидкий у роботі, добре підходить для коротких повідомлень; не враховує контекст або інтенсивність емоцій.
SentiWordNet	Позитивність / негативність / об'єктивність (0–1)	Дозволяє розглядати багатозначність слів, базується на WordNet; складна структура, не завжди зручна для прямої інтеграції.

Продовження таблиці 2.1

LIWC	Психосоціальні категорії, у тому числі емоційні	Забезпечує глибокий психологічний аналіз тексту; платний продукт, здебільшого орієнтований на англомовні корпуси.
NRC Emotion Lexicon	8 базових емоцій (радість, страх, гнів тощо) – бінарна	Має широку емоційну палітру, корисний для побудови емоційних профілів; не враховує силу емоційного вираження або контекст.

Однією з головних переваг лексичних методів є їх висока обчислювальна ефективність. Вони не потребують етапу навчання на великих корпусах, що є обов'язковим для більшості статистичних або нейромережових підходів [12]. Це робить лексичні моделі особливо привабливими для систем із обмеженими ресурсами або для задач, де критично важливим є швидке прийняття рішення в реальному часі.

Ще одним важливим аспектом є інтерпретованість результатів. У лексичних системах завжди можна з'ясувати, яке саме слово вплинуло на оцінку тексту та чому. Це є суттєвою перевагою в галузях, де користувач має право розуміти, яким чином система дійшла того чи іншого висновку – зокрема в медицині, праві, соціальних дослідженнях або журналістиці.

Попри велику кількість переваг, лексичні методи мають низку критичних обмежень, які суттєво впливають на їхню ефективність у практичних застосуваннях [14], [15]. Однією з головних проблем є неконтекстуальність – неспроможність правильно інтерпретувати значення слова без урахування його синтаксичного оточення, граматичних залежностей або прагматичного наміру автора. Унаслідок цього система

може помилково класифікувати емоційний зміст речення, навіть якщо всі слова формально мають чітко визначену полярність.

Крім того, лексичні методи демонструють вразливість до багатозначності слів. У випадках, коли слово може мати різні значення залежно від контексту (наприклад, «гострий» як характеристика болю, смаку або розуму), лексичні ресурси рідко враховують семантичну неоднозначність. Це призводить до зниження точності моделі, особливо при роботі з полісемічними конструкціями.

Ще одним викликом є статична природа лексиконів. Мови є живими структурами, які постійно змінюються: з'являються неологізми, змінюється семантика слів, виникають нові сленгові вирази, що активно використовуються в соціальних мережах або серед окремих мовних спільнот [10]. Лексикони, які не оновлюються регулярно, втрачають свою актуальність і точність. Ця проблема особливо актуальна для багатомовних систем аналізу тональності, де більшість існуючих лексичних ресурсів створені для англійської мови, тоді як для менш поширених мов (зокрема й української) якісні словники тональності залишаються обмеженими або взагалі відсутні.

Крім того, багато лексиконів не враховують фразеологізмів, стійких словосполучень або контекстно залежних конструкцій, які можуть нести емоційне навантаження лише в певному дискурсі. Наприклад, вислів «підлив масла у вогонь» не має жодного полярного слова за своєю формою, однак очевидно вказує на емоційно насичену ситуацію.

Залежність від якості, повноти та актуальності лексичної бази є ще одним фундаментальним обмеженням. Навіть добре структуровані та відомі лексикони, як-от SentiWordNet або AFINN, не охоплюють усього розмаїття мовних одиниць, що використовуються у повсякденному спілкуванні [15]. Для досягнення вищої точності необхідне або регулярне доповнення словників, або автоматизована побудова нових лексиконів на основі корпусного аналізу з елементами машинного навчання.

Зважаючи на зазначене, сучасні підходи все частіше комбінують лексичні методи з контекстно-залежними моделями, зокрема трансформерами, які можуть компенсувати недоліки словникового аналізу. Проте навіть у таких системах лексичний компонент залишається важливим – як джерело інтерпретованих ознак або як механізм фільтрації низькоякісних вхідних даних.

З метою підвищення точності та релевантності емоційного аналізу тексту в реальних умовах, сучасні лексичні підходи все частіше адаптуються до специфіки окремих сфер застосування [10]. Така адаптація передбачає врахування доменної специфіки мовлення, лексичних особливостей цільової аудиторії, стилістичних характеристик жанру тексту тощо. Зокрема, розроблено спеціалізовані лексикони для аналізу контенту в соціальних мережах (наприклад, Twitter, Facebook, Reddit), де мова є особливо неформальною, насиченою сленгом, емодзі, скороченнями та навіть візуальними символами. Інші лексикони орієнтовані на обробку онлайн-оглядів товарів, сервісів або фільмів, де важливо враховувати контекст задоволеності, очікувань і досвіду споживача [12].

Загалом, лексичні методи виступають фундаментальним компонентом гібридних систем емоційного аналізу, де поєднуються переваги різних підходів. У таких системах результати лексичного аналізу можуть бути використані як окремі ознаки (features) для подальшого навчання моделей машинного навчання або глибоких нейронних мереж. Наприклад, емоційні оцінки слів, обчислені на основі лексиконів, можуть стати вхідними параметрами для класифікаторів, таких як SVM або LSTM, що дозволяє враховувати як статистичну, так і семантичну інформацію [20].

Однією з найперспективніших тенденцій є інтеграція лексичних методів із контекстно-залежними моделями, зокрема трансформерними архітектурами (BERT, RoBERTa, DistilBERT), які враховують взаємозв'язки між словами у реченні та дозволяють моделі краще розуміти тональність складних висловлювань. У таких системах лексичний компонент виконує

роль інтерпретованого модуля попередньої обробки або підсилювача уваги, що підвищує загальну точність класифікації.

Лексичні методи аналізу емоційної тональності текстів відіграють важливу роль у задачах класифікації настроїв завдяки своїй простоті, обчислювальній ефективності та високій інтерпретованості результатів. Використання попередньо сформованих лексиконів дозволяє швидко оцінити емоційний зміст тексту без потреби в навчанні моделей на великих корпусах. Такі методи є особливо ефективними у випадках обробки коротких текстів, а також у системах, де необхідна прозорість прийнятих рішень.

Водночас обмеження лексичних підходів, зокрема нечутливість до контексту, труднощі з інтерпретацією заперечень, іронії та багатозначних слів, знижують їхню точність у складних мовних конструкціях. Через це сучасні дослідницькі підходи дедалі частіше комбінують лексичний аналіз із контекстно-залежними моделями, використовуючи лексикони як модулі попередньої обробки або джерела інтерпретованих ознак. Таким чином, лексичні методи зберігають свою актуальність у сучасному ландшафті обробки природної мови як основа для гібридних систем емоційної класифікації.

2.2 Статистичні методи та класичне машинне навчання

На відміну від лексичних методів, які ґрунтуються на заздалегідь сформованих словниках з емоційними маркерами, статистичні методи класифікації текстів використовують формальні математичні моделі для аналізу текстових даних, визначення статистичних закономірностей і подальшого віднесення тексту до певної емоційної категорії [12]. Ці методи ґрунтуються на ідеї, що текст можна подати у вигляді числових ознак, які можна обробити так само, як будь-які інші дані у задачах класифікації. Завдяки цьому емоційне забарвлення повідомлень виявляється шляхом

виявлення кореляцій між статистичними характеристиками та цільовими етикетками (позитивний, негативний, нейтральний тощо).

Статистичний підхід є особливо цінним у контексті автоматизації обробки великих обсягів інформації, де ручне анотоване кодування або використання фіксованих словників є малоефективним або взагалі неможливим [3]. Замість цього моделі навчаються розпізнавати шаблони у тексті на основі аналізу розподілу слів, частоти їх вживання та інших числових метрик. Це дозволяє виявити латентні (приховані) закономірності, які могли бути непомітні для людини або непридатні для лексичного аналізу. Наприклад, статистичні моделі здатні враховувати характерні поєднання слів або тенденції до використання певної лексики у різних емоційних контекстах, що особливо важливо в умовах неоднозначності та варіативності мови.

На практиці застосування статистичних методів передбачає низку етапів, кожен з яких відіграє важливу роль у досягненні високої точності класифікації. Перший з них – попередня обробка тексту, яка включає очищення, нормалізацію, токенізацію, лематизацію або стемінг, а також видалення стоп-слів. Ці дії спрямовані на зменшення шуму в даних та стандартизацію лексичних одиниць. Після цього текст трансформується у векторне представлення, що дозволяє подати кожен документ у вигляді числового вектора у багатовимірному просторі ознак. Для цього найчастіше використовують методи Bag of Words, TF, TF-IDF або Word Embeddings, які відображають частотні та семантичні властивості лексем [2], [3].

Наступним етапом є побудова та навчання моделі класифікації. Тут застосовуються алгоритми класичного машинного навчання, такі як наївний байєсівський класифікатор, логістична регресія, метод опорних векторів (SVM), випадковий ліс (Random Forest) тощо [14]. Навчання відбувається на анотованих корпусах – текстових вибірках, у яких кожен приклад має мітку емоційного класу. Після етапу тренування модель може використовуватися для прогнозування емоційного стану нових, раніше не

бачених текстів, що робить її особливо цінною для задач моніторингу настроїв, модерації коментарів, аналізу репутації брендів, зворотного зв'язку від користувачів тощо.

У сукупності, описані етапи формують цілісний підхід до класифікації емоційного забарвлення тексту, що поєднує попередню обробку, побудову числового представлення, навчання моделі та безпосереднє прогнозування тональності [2], [11]. Візуалізація цієї послідовності представлена на рисунку 2.2, де схематично зображено логіку проходження тексту через ключові аналітичні блоки: від моменту надходження необробленої інформації до отримання остаточного емоційного висновку. Такий підхід забезпечує не лише структурованість процесу, а й дає змогу легко масштабувати систему, інтегрувати нові алгоритми та адаптувати її до специфіки конкретних мовних або галузевих даних. Завдяки цьому статистичні методи залишаються актуальним інструментом у задачах аналізу настроїв у соціальних мережах, клієнтських відгуках, новинному контенті тощо.



Рисунок 2.2 – Етапи класифікації емоцій у тексті за статистичним підходом

У межах статистичних підходів до класифікації емоційного забарвлення текстів алгоритми класичного машинного навчання відіграють ключову роль. Вони дозволяють створювати моделі, які здатні автоматично навчатися на основі розмічених текстових корпусів і прогнозувати емоційні мітки для нових текстів. Завдяки своїй обчислювальній ефективності, відносній простоті реалізації та високій швидкодії, ці методи широко застосовуються в практиці аналізу текстових даних, зокрема в бізнес-аналітиці, обробці клієнтських відгуків, соціальних мережах, службах підтримки та журналістиці.

До найпоширеніших моделей відносяться наївний байєсівський класифікатор (Naïve Bayes), логістична регресія (Logistic Regression), метод опорних векторів (SVM), ансамблевий метод випадкових лісів (Random Forest) та метод k найближчих сусідів (k -NN) [15]. Кожен з цих алгоритмів має унікальні характеристики, переваги та сфери оптимального застосування, що дозволяє гнучко адаптувати їх до різних сценаріїв класифікації.

Залежно від поставленої задачі, обсягу наявних даних та вимог до продуктивності, для автоматичної класифікації емоцій у текстах можуть застосовуватись різні алгоритми машинного навчання. Кожен з них має свої сильні сторони, обмеження та особливості функціонування. У практичних системах аналізу емоцій класифікатори часто підбираються не лише за критерієм точності, а й за додатковими факторами – такими як потреба у поясненні рішення, здатність до роботи з незбалансованими даними, стійкість до шуму, наявність або відсутність великого анотованого корпусу. Застосування певного алгоритму також залежить від структури ознак, способу векторизації тексту, кількості категорій емоцій та типу задачі (бінарна чи мультикласова класифікація). У таблиці 2.2 представлено порівняльну характеристику найуживаніших моделей класичного машинного навчання, що на практиці продемонстрували ефективність у сфері аналізу емоційної тональності текстів.

Таблиця 2.2 – Основні алгоритми класичного машинного навчання для класифікації емоцій у текстах

Алгоритм	Опис
Naïve Bayes	Ймовірнісний алгоритм, що використовує теорему Байєса з припущенням незалежності ознак. Визначає клас тексту на основі частоти слів. Швидко працює з великими обсягами тексту та ефективний для коротких повідомлень.
Support Vector Machines (SVM)	Побудова гіперплощини, яка максимально розділяє дані за класами. Підтримує використання ядрових функцій для роботи з нелінійними розподілами. Стійкий до перенавчання, особливо ефективний для задач з високою розмірністю ознак.
Logistic Regression	Лінійна модель, яка прогнозує ймовірність належності тексту до певного класу на основі логістичної функції. Простий і швидкий метод, добре підходить для задач з двома або кількома класами.
Random Forest	Ансамблевий метод, що об'єднує велику кількість дерев ухвалення рішень. Зменшує ймовірність перенавчання та забезпечує стабільні результати на шумових або незбалансованих даних.
k-Nearest Neighbors (k-NN)	Нелінійний метод, який класифікує нові тексти за найбільш схожими сусідніми прикладами у векторному просторі. Прямолінійний у реалізації, але потребує багато пам'яті й повільний при великих обсягах даних.

У порівнянні з більш складними нейронними мережами, класичні алгоритми машинного навчання мають низький поріг входу та швидку адаптацію до нових задач. Їхня пояснюваність – одна з ключових переваг:

аналітик може чітко простежити, чому модель зробила той чи інший висновок, що особливо важливо в юридичних, медичних або соціальних сферах. Наприклад, логістична регресія дозволяє легко інтерпретувати ваги кожного ознакового вектора, а Random Forest – виявити найбільш впливові ознаки завдяки оцінці важливості характеристик (feature importance).

Однак разом із перевагами існує низка обмежень. Найважливішим із них є чутливість до якості навчальних даних. Недостатньо розмічений або нерепрезентативний корпус може призвести до систематичних помилок. Крім того, більшість класичних моделей не мають вбудованого уявлення про контекст, що унеможливорює точне розпізнавання емоцій у фразах з багатозначними словами, іронією або запереченнями [3]. Наприклад, метод Naïve Bayes не враховує послідовність слів, а отже може неправильно трактувати фрази типу «не погано».

Ще одне важливе обмеження – необхідність ручної інженерії ознак. Для досягнення високої точності класифікації розробник має ретельно підібрати або згенерувати найбільш інформативні характеристики тексту, що потребує фахових знань та експериментів [11]. У протилежність цьому, сучасні нейронні мережі здатні самостійно навчатися векторних представлень і виявляти складні нелінійні залежності між словами.

Незважаючи на зазначені обмеження, класичні моделі залишаються ефективним базовим інструментом, особливо у проектах з обмеженими ресурсами, де потрібна швидка реалізація та легка підтримка. Вони також часто застосовуються як еталон (baseline) для порівняння з більш складними підходами або використовуються в гібридних архітектурах як окремі блоки попереднього аналізу, що пришвидшує обчислення і зменшує навантаження на глибокі моделі.

Статистичні методи та алгоритми класичного машинного навчання забезпечують ефективний інструментарій для автоматизованої класифікації емоційного забарвлення текстів. Завдяки поєднанню обчислювальної ефективності, високої швидкодії та пояснюваності, ці підходи дозволяють

розробляти гнучкі моделі, здатні працювати з великими обсягами текстових даних без втрати точності. Застосування таких алгоритмів, як Naïve Bayes, SVM, Logistic Regression, Random Forest та k-NN, демонструє високу продуктивність у задачах аналізу настроїв за умови якісної підготовки вхідних ознак.

Разом з тим, відсутність контекстної чутливості, залежність від інженерії ознак і обмежена здатність до узагальнення у складних мовних конструкціях залишаються суттєвими бар'єрами для повноцінної інтерпретації емоцій. У зв'язку з цим, на сучасному етапі розвитку NLP такі методи часто розглядаються як базова основа або складова частина більш комплексних гібридних архітектур, у яких їхні сильні сторони доповнюються можливостями глибокого навчання. Попри конкуренцію з боку нейромережевих моделей, статистичні підходи залишаються затребуваними у випадках, де потрібні швидкість, прозорість і низькі обчислювальні витрати.

2.3 Методи глибокого навчання

У сучасній практиці аналізу емоцій тексту глибоке навчання відіграє провідну роль, забезпечуючи високу точність класифікації завдяки здатності моделювати складні нелінійні залежності та враховувати глибокий контекст висловлювань. На відміну від лексичних і статистичних методів, які базуються на поверхневих ознаках або ручному формуванні ознак, глибокі нейронні мережі здатні самостійно навчатися узагальненим уявленням про текст і виявляти приховані семантичні структури [21]. Це робить їх особливо ефективними у задачах класифікації емоцій, де важливо точно інтерпретувати як загальний настрій, так і нюанси мовлення.

Однією з ключових переваг глибокого навчання є можливість контекстуалізації значення слів у тексті. Завдяки використанню трансформерних архітектур, таких як BERT, RoBERTa, GPT, моделі можуть

враховувати залежності між словами на довгих відстанях, а також правильно інтерпретувати багатозначні терміни, фразеологізми, заперечення та іронічні конструкції [8]. Наприклад, слово «приємний» у фразі «неприємний досвід» може бути класифіковано неправильно класичними методами, але контекстно-залежна модель здатна врахувати заперечення та надати відповідну оцінку.

Процес аналізу емоційного забарвлення тексту за допомогою глибокого навчання передбачає кілька етапів, які подано на рисунку 2.3.



Рисунок 2.3 – Архітектура глибокого аналізу емоцій тексту

Спочатку здійснюється попередня обробка текстових даних: очищення тексту, приведення до нижнього регістру, токенізація (розбиття на слова або субслова), видалення стоп-слів та перетворення тексту в числову форму. Для деяких моделей, зокрема трансформерів, застосовується спеціалізована токенізація, як-от WordPiece або Byte Pair Encoding, що забезпечує гнучкість у роботі з новими або рідковживаними словами.

Далі відбувається етап векторизації, під час якого текст трансформується у вигляд числових векторів. Статичні моделі, як-от Word2Vec і GloVe, представляють кожне слово фіксованим вектором незалежно від контексту. Натомість сучасні моделі на кшталт BERT або ELMo формують контекстуальні вектори, які відображають значення слова залежно від його оточення. Це особливо важливо у випадках омонімії або контекстуальних зсувів значення.

Після векторизації на основі отриманих представлень відбувається навчання нейронної мережі. Моделі тренуються на попередньо анотованих корпусах текстів, де кожному прикладу відповідає певна емоційна мітка – полярність (позитивна, негативна, нейтральна) або категоріальні емоції (радість, сум, гнів тощо). У процесі навчання модель оптимізує ваги, які дозволяють їй узагальнювати закономірності, що пов'язують вхідні тексти з відповідними емоційними станами. Серед найпоширеніших архітектур – рекурентні мережі (RNN, LSTM, GRU), згорткові мережі (CNN) та трансформери (BERT, GPT) [21], [22].

Після завершення етапу тренування модель переходить до фази інференсу, тобто класифікації нових текстів. На вхід подається текст, що проходить описані вище етапи обробки, а на виході система повертає прогнозовану емоційну категорію або вектор оцінок за декількома шкалами. Можливості глибоких моделей дозволяють отримувати більш точні й диференційовані результати порівняно з традиційними алгоритмами, особливо в умовах складних мовних конструкцій або неоднозначних емоційних сигналів.

У таблиці 2.3 продемонстровано порівняльну характеристику найефективніших моделей глибокого навчання, які демонструють високу результативність у задачах емоційної класифікації. Це дозволяє наочно оцінити їхні переваги, обмеження та застосовність у різних умовах аналізу текстових даних.

Таблиця 2.3 – Порівняння моделей глибокого навчання для аналізу емоцій

Модель	Опис	Переваги	Недоліки
RNN	Базова модель для обробки послідовностей	Добре враховує порядок слів	Погано обробляє довгі послідовності, проблема з градієнтами
LSTM	Удосконалена RNN з блоками пам'яті	Добре зберігає контекст, стійка до затухання градієнтів	Складна архітектура, потребує більше ресурсів
GRU	Спрощена версія LSTM	Менше параметрів, швидше тренування	Трохи нижча точність порівняно з LSTM у деяких задачах
CNN	Згорткова мережа, що виділяє локальні патерни	Висока швидкість, паралелізується	Не враховує контекст на глобальному рівні
BERT	Трансформер із двобічною увагою	Висока точність, контекстно залежне представлення	Важкий для навчання, потребує великих обчислень
GPT	Генеративна трансформерна модель	Добре моделює послідовність, потужна генерація	Потребує великого обсягу даних, погано працює без донавчання

Переваги глибокого навчання полягають у високій точності навіть у складних мовних випадках, здатності обробляти великі корпуси неструктурованих текстових даних та можливості донавчання на вузькоспеціалізованих доменах [8]. Завдяки гнучкості й масштабованості ці підходи ефективно застосовуються у сфері автоматизованого моніторингу настроїв, виявлення токсичних висловлювань, обробки користувацьких відгуків, модерації коментарів і побудови діалогових систем.

Разом з тим існують і недоліки, характерні для моделей глибокого навчання. Зокрема, їхня обчислювальна вимогливість потребує наявності потужного апаратного забезпечення, що обмежує використання в реальному часі на малопотужних пристроях [8], [22]. Крім того, висока складність архітектур утруднює інтерпретацію результатів, що є критичним чинником у сферах, де потрібна прозорість прийняття рішень. Ще однією проблемою є потреба у великій кількості якісно анотованих даних, без яких повноцінне навчання моделі стає неможливим.

Актуальні дослідження спрямовані на подолання вказаних обмежень. Впровадження трансферного навчання дозволяє використовувати попередньо натреновані моделі навіть у випадках обмеженого доступу до даних. Методи *few-shot* та *zero-shot* навчання забезпечують здатність моделі до узагальнення без великого обсягу тренувальних прикладів [21]. Крім того, у практиці дедалі частіше застосовуються техніки пояснюваного ШІ (Explainable AI) – такі як SHAP або LIME, що дають змогу зрозуміти логіку класифікації навіть у складних багаторівневих мережах.

Таким чином, глибоке навчання становить сучасний стандарт у задачах аналізу емоційної тональності текстів і є незамінним інструментом для високоточного моделювання емоцій. Його здатність адаптуватися до особливостей природної мови, враховувати контекст, розпізнавати приховані патерни та забезпечувати конкурентну точність дозволяє створювати системи, які перевершують класичні методи за результатами. Постійне вдосконалення архітектур, поява нових відкритих моделей і

розвиток бібліотек робить глибоке навчання доступнішим навіть для невеликих проєктів. У майбутньому ці технології, ймовірно, стануть основою для універсальних інтерпретаторів настроїв і емоцій у багатомовному середовищі, а також рушієм для нових досягнень у сфері когнітивної обробки мови, психологічного аналізу тексту та персоналізованої взаємодії людини з машиною.

Такі моделі вже знаходять широке застосування в комерційних і наукових розробках, зокрема в системах аналізу споживчих настроїв, автоматизованих службах підтримки та цифрових асистентах. Завдяки здатності до навчання на великих корпусах природномовних текстів, вони можуть враховувати мовні нюанси, регіональні особливості й стилістичні варіації. Крім того, сучасні моделі глибокого навчання все частіше підтримують механізми пояснюваності, що дозволяє аналізувати причини певних емоційних рішень і підвищує довіру до результатів. У контексті стрімкого зростання обсягів текстових даних особливу цінність набуває можливість масштабування таких рішень із мінімальними витратами часу на додаткове налаштування. Усе це свідчить про те, що глибоке навчання не лише стало стандартом у сфері аналізу емоцій, а й визначає напрям подальшого розвитку інтелектуальних мовних систем.

3 РОЗРОБКА КОМБІНОВАНОГО МЕТОДУ АНАЛІЗУ ТОНАЛЬНОСТІ ТЕКСТІВ

3.1 Архітектура методу

Запропонований комбінований метод визначення емоційного забарвлення текстів ґрунтується на поєднанні лексичних, статистичних і контекстуальних підходів для досягнення максимальної точності у класифікації емоцій. Основна ідея методу полягає в тому, щоб інтегрувати переваги класичних методів машинного навчання, які працюють із лексичними ознаками, із сучасними можливостями глибоких нейронних мереж, зокрема трансформерів, здатних враховувати контекст і семантичні зв'язки між словами [4]. Архітектура методу передбачає чітко визначену послідовність етапів, кожен з яких відіграє ключову роль у забезпеченні високої якості результатів. Основні етапи архітектури подано на рисунку 3.1.

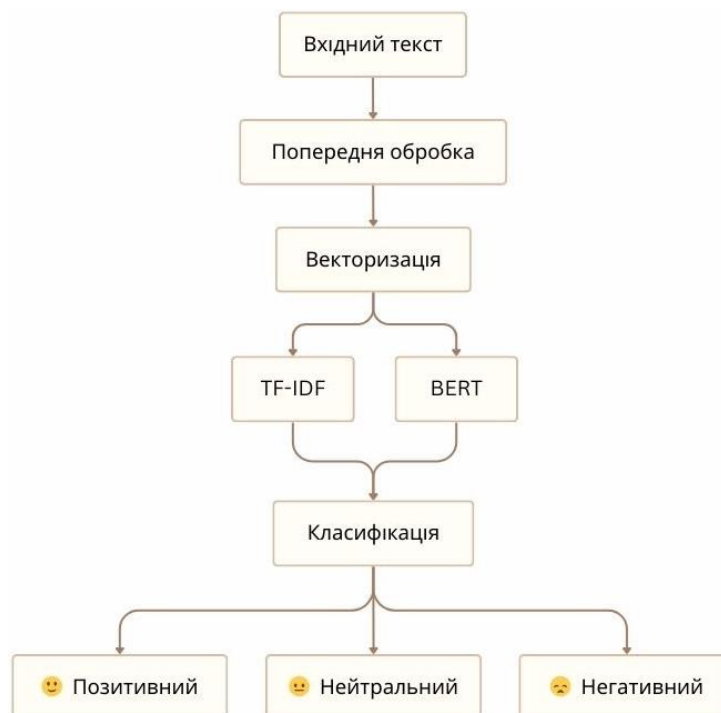


Рисунок 3.1 – Архітектура комбінованого методу класифікації емоцій

Першим етапом є попередня обробка тексту. На цьому етапі вхідний текст проходить стандартні процедури очищення: видалення зайвих символів, пунктуації, HTML-тегів, зниження регістру, а також лематизація – приведення слів до їхньої базової форми. Також здійснюється видалення стоп-слів, які не несуть значущого семантичного навантаження. Цей крок сприяє зменшенню шуму в даних та покращенню якості подальших перетворень.

Другий етап – векторизація тексту, який реалізується паралельно двома шляхами. Перший шлях – лексичне векторне представлення тексту, зокрема через TF-IDF (Term Frequency – Inverse Document Frequency). Цей метод дозволяє відобразити статистичну значущість кожного терміна у тексті з урахуванням його частоти у документі та у всьому корпусі. У запропонованій архітектурі TF-IDF використовується для побудови векторів фіксованої довжини (5000 найбільш релевантних ознак), які передають частотну і тематичну інформацію про текст.

Другий шлях – контекстуальне представлення тексту за допомогою трансформерної моделі BERT (Bidirectional Encoder Representations from Transformers). Замість використання BERT у режимі fine-tuning, обрано режим feature extraction: текст пропускається через попередньо натреновану модель bert-base-uncased, і з нього видобувається векторне представлення, отримане шляхом усереднення CLS-токенів з останнього шару моделі. Це дозволяє отримати глибоко семантизоване уявлення про зміст тексту, що враховує контекстне вживання слів у реченні.

Третій етап передбачає інтеграцію ознак з обох представлень: TF-IDF та BERT-векторів. Отримані два векторні простори з'єднуються в єдиний гібридний вектор шляхом конкатенації. Такий підхід дозволяє комбінувати статистичні закономірності з семантичними зв'язками, що значно розширює інформаційне поле для класифікації та знижує ймовірність втрати важливих ознак.

Четвертим етапом є класифікація за допомогою моделі машинного навчання. У запропонованій архітектурі використовується Random Forest Classifier – ансамблевий метод, що базується на рішенні колективу дерев ухвалення рішень. Цей алгоритм обрано через його стійкість до переобучення, здатність працювати з великими масивами ознак і високу інтерпретованість результатів. Конкретна конфігурація моделі включає 300 дерев, максимальну глибину 20 та мінімальну кількість зразків у листі – 2.

Для оптимізації продуктивності та зменшення ризику переобучення, перед навчанням класифікатора здійснюється стандартизація ознак [2]. Усі вектори нормалізуються до єдиного діапазону значень. Крім того, частина даних відкладається для валідації – у співвідношенні 80:20, що забезпечує можливість об'єктивної оцінки ефективності моделі на нових текстах.

На завершальному етапі модель використовується для передбачення емоційного забарвлення текстів, що не входили до навчального набору. Вихідним результатом є прогноз емоційної категорії (позитивна, негативна або нейтральна) разом із ймовірнісною оцінкою, яка дає змогу враховувати рівень упевненості моделі у власному рішенні.

У структурному плані метод реалізується як послідовність модулів, кожен з яких відповідає за конкретну функцію. Завдяки модульності реалізації, його можна легко адаптувати до нових задач або замінити окремі компоненти на більш досконалі – наприклад, використати замість TF-IDF більш сучасні методи векторизації, як-от BM25, або змінити базову трансформерну модель BERT на RoBERTa чи DistilBERT [3], [4].

У таблиці 3.1 наведено порівняння модулів, що входять до складу комбінованого методу, із зазначенням їх призначення та особливостей реалізації. Такий підхід дозволяє не лише структуровано представити функціональність кожного елемента, а й забезпечує аналітичне підґрунтя для подальшої оптимізації або модифікації окремих складових. Це особливо важливо при масштабуванні системи або адаптації до нових наборів даних та мовних доменів.

Таблиця 3.1 – Компоненти гібридного методу

Компонент	Призначення	Особливості реалізації
TF-IDF	Статистичне подання тексту	Вектор 5000 ознак, частотний розподіл
BERT	Контекстуальне представлення	Усереднення CLS-токенів з останнього шару
Конкатенація	Об'єднання ознак	Злиття двох векторів у єдиний вектор ознак
Random Forest	Класифікація	300 дерев, max_depth=20, min_samples_leaf=2
Стандартизація	Уніфікація масштабів	Z-score normalization перед подачею в модель

Таким чином, архітектура запропонованого методу є гнучкою, масштабованою та орієнтованою на поєднання різнорівневих ознак для досягнення максимальної точності у задачах емоційної класифікації текстів. Її комбінований характер дозволяє ефективно використовувати як експліцитні, так і латентні знання, закладені у тексті, що робить метод конкурентоспроможним серед сучасних рішень у галузі аналізу тональності. Крім того, запропонована архітектура демонструє здатність до інтеграції з новими технологіями, що дає змогу покращувати її з часом без повного перепроекування. Завдяки цьому метод має потенціал для подальшого розвитку, включно з адаптацією до багатомовного середовища, обробки доменно-специфічного контенту та розширення спектра емоційних категорій. Така універсальність робить його ефективним інструментом як у дослідницьких цілях, так і в реальних застосуваннях, включаючи моніторинг соціальних мереж, аналіз відгуків користувачів та системи емоційної аналітики для бізнесу й медіа.

3.2 Інструменти та параметри реалізації

Реалізація запропонованого комбінованого методу визначення емоційного забарвлення текстів потребує ретельного підбору інструментів, які б забезпечили ефективну обробку текстових даних, побудову векторних представлень, тренування моделі класифікації та проведення повного циклу експериментів.

Для реалізації методу було обрано мову програмування Python, яка є найбільш поширеною у сфері обробки природної мови (NLP) і машинного навчання [17]. Python має розвинену екосистему бібліотек для обробки текстів, векторизації, роботи з моделями глибокого навчання та візуалізації результатів.

Розглянемо детально основні бібліотеки, задіяні у процесі реалізації.

Pandas – це ключова бібліотека для роботи з табличними структурами даних у Python, яка дозволяє зручно зчитувати, обробляти та аналізувати великі обсяги інформації у форматі DataFrame. Вона забезпечує широкий набір функцій для фільтрації, агрегації, групування та об'єднання даних, що є критично важливим під час попередньої обробки текстових корпусів.

NumPy – це фундаментальна бібліотека для роботи з багатовимірними масивами і матрицями, що підтримує ефективні векторні операції. Завдяки NumPy забезпечується швидка обробка числових даних, що використовується, зокрема, при об'єднанні ознак, обчисленні статистик або підготовці векторів для моделей.

Scikit-learn – одна з найпопулярніших бібліотек машинного навчання, яка надає інструменти для класифікації, регресії, кластеризації, а також зручні засоби для оцінювання моделей.

Transformers (від Hugging Face) – це сучасна бібліотека для роботи з передовими трансформерними моделями, зокрема BERT, GPT, RoBERTa та іншими. Вона забезпечує легкий доступ до попередньо натренованих

мовних моделей і дозволяє ефективно витягувати контекстуальні вектори з тексту.

Torch (PyTorch) – це гнучкий фреймворк для реалізації моделей глибокого навчання, який підтримує автоматичне диференціювання, GPU-прискорення і гнучке створення нейронних мереж. Він широко використовується для інтеграції з бібліотекою Transformers та забезпечує низькорівневий контроль над обчисленнями у нейронних мережах.

Matplotlib та Seaborn – це бібліотеки для створення графіків і візуалізації даних. Matplotlib забезпечує базові можливості побудови графіків, тоді як Seaborn дозволяє створювати більш естетичні, статистично орієнтовані візуалізації.

У таблиці 3.2 представлено конкретне застосування цих бібліотек в межах реалізації комбінованого методу визначення емоційного забарвлення текстів.

Таблиця 3.2 – Використання бібліотек у гібридному методі

Бібліотека	Використання
Pandas	Організація даних про твіти, мітки емоцій та результати класифікації.
NumPy	Об'єднання TF-IDF і BERT-векторів, числові обчислення.
Scikit-learn	TF-IDF, навчання Random Forest, стандартизація, розрахунок метрик, розбиття даних.
Transformers (від Hugging Face)	Отримання семантичних векторів тексту через попередньо навчену BERT.
Torch (PyTorch)	Обчислення hidden-станів із BERT, обробка результатів.
Matplotlib та Seaborn	Візуалізація результатів, аналіз точності, розподілу та плутанини.

Далі розглянемо ключові фрагменти реалізації коду, що відображають підготовку даних, побудову комбінованих векторів, навчання моделі класифікації та візуалізацію результатів.

У лістингу 3.1 наведено підключення необхідних бібліотек, що забезпечують обробку текстових даних, векторизацію, навчання моделі та візуалізацію результатів.

Лістинг 3.1 – Підключення основних бібліотек

```
import pandas as pd
import numpy as np
from sklearn.feature_extraction.text import
TfidfVectorizer
from sklearn.ensemble import RandomForestClassifier
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import classification_report,
confusion_matrix
import torch
from transformers import BertTokenizer, BertModel
import matplotlib.pyplot as plt
import seaborn as sns
```

Наступний етап – завантаження набору даних:

```
df = pd.DataFrame(data)
```

Векторизація текстів за допомогою TF-IDF – цей етап передбачає перетворення тексту у вектори, що відображають частотність слів:

```
tfidf = TfidfVectorizer(max_features=100)
X_tfidf = tfidf.fit_transform(data['text']).toarray()
```

У лістингу 3.2 продемонстровано процес отримання контекстних векторів за допомогою попередньо натренованої моделі bert-base-uncased. Цей етап забезпечує глибоке представлення семантики кожного тексту та підвищує якість подальшої класифікації.

Лістинг 3.2 – Отримання BERT-векторів

```
tokenizer = BertTokenizer.from_pretrained('bert-base-uncased')
model = BertModel.from_pretrained('bert-base-uncased')
def get_bert_vector(text):
    inputs = tokenizer(text, return_tensors='pt',
truncation=True, padding=True)
    with torch.no_grad():
        outputs = model(**inputs)
    return outputs.last_hidden_state[:, 0, :].numpy()
X_bert = np.vstack([get_bert_vector(text) for text in
data['text']])
```

Програмний код об'єднання статистичних та контекстних ознак у єдину матрицю ознак поданий у лістингу 3.3. Після цього здійснюється масштабування ознак та розділення вибірки на навчальну та тестову для подальшого тренування моделі.

Лістинг 3.3 – Об'єднання ознак та підготовка даних

```
X_combined = np.hstack((X_tfidf, X_bert))
scaler = StandardScaler()
X_scaled = scaler.fit_transform(X_combined)
y = data['label']
X_train, X_test, y_train, y_test =
train_test_split(X_scaled, y, test_size=0.2,
random_state=42)
```

На наступному етапі здійснюється навчання моделі класифікації типу **Random Forest** на основі попередньо підготовлених комбінованих ознак, що об'єднують статистичне та контекстуальне представлення текстів:

```
model_rf = RandomForestClassifier(n_estimators=300,
max_depth=20, min_samples_leaf=2)
model_rf.fit(X_train, y_train)
```

Фінально модель перевіряється на тестовій вибірці. Результати відображаються через метрики і матрицю плутанини. Програмний код оцінки точності та візуалізації поданий у лістингу 3.4.

Лістинг 3.4 – Оцінка точності та візуалізація

```
y_pred = model_rf.predict(X_test)
print(classification_report(y_test, y_pred))
cm = confusion_matrix(y_test, y_pred,
                      labels=model_rf.classes_)
sns.heatmap(cm, annot=True, fmt='d', cmap='Blues',
            xticklabels=model_rf.classes_,
            yticklabels=model_rf.classes_)
plt.xlabel('Predicted')
plt.ylabel('Actual')
plt.title('Confusion Matrix')
plt.show()
```

Таким чином, ефективна реалізація комбінованого методу класифікації емоційного забарвлення текстів стала можливою завдяки інтеграції широкого спектра програмних інструментів і бібліотек Python, кожна з яких відіграє специфічну роль у загальній архітектурі рішення. Використання Pandas і NumPy забезпечило надійну платформу для попередньої обробки й агрегації даних, тоді як Scikit-learn дозволила реалізувати ключові етапи векторизації, навчання моделі, масштабування ознак і побудови метрик ефективності.

Застосування бібліотеки Transformers у поєднанні з PyTorch дало змогу інтегрувати сучасні трансформерні представлення тексту, зокрема BERT, що значно підвищило якість ознак за рахунок урахування контексту. Системний підхід до підбору інструментів та параметрів реалізації сприяв створенню гнучкого, модульного і легко масштабованого рішення, здатного адаптуватися до різних мовних корпусів, задач і форматів даних.

4 ЕКСПЕРИМЕНТАЛЬНА ПЕРЕВІРКА ЕФЕКТИВНОСТІ КОМБІНОВАНОГО МЕТОДУ

4.1 Опис умов проведення експерименту

Для експериментального дослідження було використано набір даних з емоційної класифікації англomовних твітів, доступний на платформі Kaggle – Emotion Dataset for NLP. Цей датасет містить короткі повідомлення з мітками емоцій, які відповідають певним емоційним станам автора.

В оригінальному варіанті набір включає понад 20000 рядків тексту, які містять емоційні мітки з таких категорій, як joy, anger, sadness, fear, love, surprise тощо. Для спрощення задачі та приведення її до трикласової моделі (позитивна, негативна, нейтральна), було здійснено агрегування класів:

- позитивні: joy, love, surprise;
- негативні: anger, sadness, fear;
- нейтральні: невиражені або конфліктні випадки.

Балансування класів було досягнуто шляхом підсумовування підвибірок, щоб уникнути домінування одного емоційного класу. Перед векторизацією всі тексти пройшли однаково обробку: зниження регістру, видалення пунктуації та спеціальних символів, токенізація, видалення стоп-слів. Ці процедури дозволили уніфікувати структуру тексту, покращити якість векторизації та зменшити розмірність вхідного простору.

Як зазначено в архітектурі, комбінований метод реалізує концепцію двоканального опрацювання текстових даних, що передбачає паралельне використання двох незалежних, але комплементарних підходів до векторного представлення:

- TF-IDF: для обчислення було обрано 5000 найпоширеніших термінів. Використано TfidfVectorizer зі стандартними параметрами,

включно з $ngram_range=(1,2)$ та $max_df=0.9$, щоб відсіяти занадто часті слова. Результатом є розріджена матриця розміром $n \times 5000$;

– BERT (base-uncased): використано модель bert-base-uncased із Hugging Face, без fine-tuning. Отримання векторів здійснювалося через обчислення CLS-токена або середнього по всіх токенах на останньому прихованому шарі. Розмірність отриманого вектора – 768.

Обидва представлення об'єднувались у єдиний вектор ознак розмірності 5768, після чого здійснювалась стандартизація за допомогою StandardScaler.

У якості класифікатора обрано Random Forest, оскільки він добре справляється з великою кількістю ознак, не потребує масштабування і стійкий до переобучення. Параметри моделі:

- $n_estimators = 300$;
- $max_depth = 20$;
- $min_samples_leaf = 2$;
- $random_state = 42$;
- $n_jobs = -1$ (для використання всіх CPU-ядер).

Модель навчалась на 80% даних, інші 20% використовувалися для тестування. Також реалізовано 5-кратну крос-валідацію для перевірки стабільності результатів.

Для оцінки ефективності моделі було використано стандартні метрики:

- Accuracy – загальна точність класифікації;
- Precision, Recall та F1-score – для кожного класу окремо;
- Confusion Matrix – візуалізація правильних і неправильних передбачень.

На рисунку 4.1 зображено матрицю плутанини, що демонструє досить високу точність класифікації, з невеликим рівнем помилок між класами, що характерно для комбінованих моделей із сильними векторними поданнями.




Рисунок 4.1 – Точність комбінованого методу

Як видно, більшість прикладів правильно класифіковані, зокрема позитивні й негативні емоції мають найвищий рівень точності. Найбільше плутанини спостерігається між класами «нейтральний» і «позитивний», що є типовим для коротких текстів, у яких емоційна тональність виражена неявно. Незначна кількість хибних спрацьовувань для негативного класу вказує на високу чутливість моделі до емоцій негативного спектра [23].

Загалом отримана матриця підтверджує ефективність комбінованого методу: поєднання статистичних і контекстуальних ознак дозволило моделі краще відрізнити тонко виражені емоційні стани, порівняно з класичними підходами.

Для того щоб оцінити ефективність комбінованого методу не лише ізольовано, але й у порівнянні з іншими поширеними методами, а саме TF-IDF + Random Forest та BERT + Random Forest, було здійснено розширене експериментальне тестування. Метою такого аналізу є визначення, наскільки даний гібридний метод випереджає базові підходи як за точністю, так і за стабільністю результатів.

На рисунку 4.2 представлено порівняння точності моделей класифікації.




Рисунок 4.2 – Порівняння точності моделей класифікації

Цей рисунок демонструє, що комбінована модель TF-IDF + BERT + Random Forest забезпечує найвищий рівень асигасу, досягаючи значення близько 89%. Це підтверджує ефективність інтеграції двох типів ознак – статистичних (TF-IDF) і контекстуальних (BERT) – у рамках одного векторного простору. Модель BERT + Random Forest показала середню точність – приблизно 82%, що вказує на добру здатність BERT моделювати контекст, однак без доповнення частотними ознаками вона поступається гібридному підходу. Найнижчу точність продемонструвала модель TF-IDF + Random Forest – близько 78%, що свідчить про її обмежену здатність враховувати глибокі семантичні зв'язки в тексті.

Порівняння F1-score для цих методів представлено на рисунку 4.3, який наочно ілюструє різницю в збалансованості точності та повноти між моделями, що базуються на різних комбінаціях ознак.

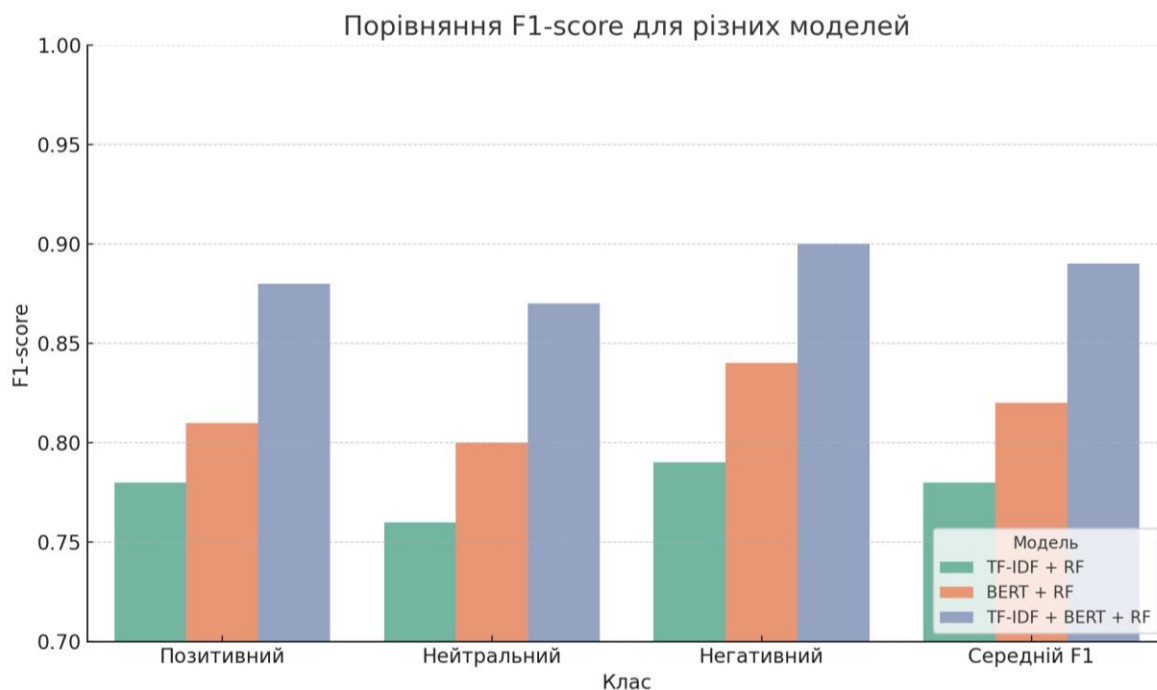


Рисунок 4.3 – Порівняння F1-score для різних моделей

Результати показали, що гібридна модель TF-IDF + BERT + RF демонструє найвищі значення F1-score для всіх трьох класів – позитивного, нейтрального та негативного. Середній F1 для цієї моделі становить близько 88%, що помітно перевищує показники інших підходів. Модель BERT + RF посіла друге місце за ефективністю, особливо добре впоравшись із класифікацією негативних повідомлень. Її результати свідчать про високу цінність контекстуального представлення, хоча в сукупності ця модель поступається комбінованому підходу. Найгірші результати показала TF-IDF + RF, яка не змогла досягти високої точності в жодному з класів. Це ще раз підкреслює обмеженість виключно частотного підходу в задачах, де важливе розуміння семантики. Гібридна модель також продемонструвала кращу стабільність між класами, забезпечуючи більш збалансовану класифікацію.

У плані обчислювальних витрат, результати яких представлені на рисунку 4.4, перевага за TF-IDF + RF, яка тренується найшвидше.




Рисунок 4.4 – Порівняння часу тренування

Модель BERT + RF потребує більше часу, тоді як комбінований метод тренується найдовше, оскільки включає обидва типи векторизації та обробку великої кількості ознак.

4.2 Оцінка отриманих результатів

Результати експериментального дослідження підтвердили ефективність запропонованого комбінованого підходу до визначення емоційного забарвлення текстів, що поєднує ознаки TF-IDF і контекстні вектори BERT. Порівняльний аналіз із базовими моделями показав, що саме гібридний метод демонструє найвищі значення асигасу та середнього F1-score, перевершуючи як моделі на основі лише лексичних ознак, так і моделі, що використовують лише BERT.

Зокрема, середнє значення F1-score для комбінованої моделі склало близько 88%, тоді як моделі TF-IDF + RF та BERT + RF дали результати на

рівні 78% та 82% відповідно. Аналогічні тенденції спостерігались і для точності класифікації: комбінована модель досягла 89%, перевершивши конкурентів. Це свідчить про те, що інтеграція статистичних та семантичних ознак забезпечує ширше охоплення особливостей тексту та покращує здатність моделі відрізняти емоційні відтінки.

Водночас, комбінований підхід потребує більше часу на тренування, що було продемонстровано у відповідних графіках. Однак ці витрати компенсуються суттєвим зростанням якості результатів. Таким чином, розроблений метод може бути рекомендований для застосування в задачах, де критичним є точне визначення емоційного забарвлення, зокрема в системах моніторингу соціальних мереж, аналізі відгуків користувачів або чат-ботах із емоційною чутливістю.

На основі проведеного експерименту можна сформулювати низку рекомендацій щодо підвищення точності аналізу емоційної тональності природномовних текстів. По-перше, доцільно комбінувати різні типи ознак – частотні, контекстуальні та синтаксичні – для отримання повнішого представлення тексту. По-друге, варто проводити розширену попередню обробку, включно з врахуванням емодзі, синонімів, синонімічних перетворень і фразеологізмів, що є носіями прихованих емоцій. Крім того, покращення може бути досягнуто за рахунок тонкого налаштування трансформерної моделі під конкретний домен або використання ensemble-підходів, що поєднують прогнози декількох моделей. У сукупності ці заходи здатні забезпечити вищу чутливість моделі до нюансів емоційної виразності, особливо в коротких повідомленнях.

Подальші дослідження можуть бути зосереджені на оптимізації швидкодії моделі, зокрема шляхом використання полегшених варіантів BERT, таких як DistilBERT або TinyBERT, а також застосування методів квантування або дистиляції знань. Також перспективним напрямом є дослідження впливу різних схем агрегування ознак, включно з attention-механізмами або autoencoder-об'єднанням векторів. У майбутньому

доцільним є адаптація методу для багатомовного середовища та доменно-специфічного аналізу, що дозволить ще ширше застосовувати запропонований підхід у реальних умовах.

Крім того, доцільним є дослідження інтеграції зовнішніх знань, наприклад, у вигляді семантичних мереж або емоційних онтологій, які можуть підсилити якість інтерпретації тексту. Застосування багаторівневого ансамблю моделей може забезпечити гнучкість та адаптивність системи до різних джерел текстових даних. Перспективним є також включення модулів самооцінювання моделі, які дозволяють оцінювати рівень впевненості у класифікаційних рішеннях. Це особливо важливо для критичних застосувань, де недостовірна емоційна інтерпретація може призвести до хибних висновків. У напрямі адаптації до реального часу доцільно розглянути гібридні архітектури, що поєднують глибоке навчання з класичними методами для досягнення компромісу між точністю та швидкістю. Також важливо досліджувати вплив різних стратегій попередньої обробки, зокрема нормалізації тексту, фільтрації шуму та виявлення іронії, які суттєво впливають на результати класифікації. Нарешті, інтеграція з інтерфейсами користувача (наприклад, візуалізація емоційної динаміки) може розширити функціональність систем та зробити їх більш зручними й інформативними для кінцевих користувачів.

ВИСНОВКИ

У межах виконаного дослідження було розглянуто сучасні підходи до визначення емоційного забарвлення природномовних текстів, здійснено їх систематизацію, порівняльний аналіз та розроблено власний комбінований метод, що поєднує статистичні й семантичні представлення для досягнення підвищеної точності класифікації емоцій.

Перш за все, було здійснено ґрунтовний аналіз предметної галузі. Розглянуто психологічні й лінгвістичні основи емоцій у текстах, різновиди класифікацій та роль емоцій у цифровій комунікації. Було встановлено, що надійне розпізнавання емоцій неможливе без врахування контексту, стилістичних засобів та лексичних особливостей мови.

На основі аналізу існуючих методів було виділено чотири основні групи: лексичні, статистичні, методи машинного навчання та гібридні підходи. Кожен з них має свої переваги та обмеження. Лексичні методи характеризуються високою інтерпретованістю та обчислювальною ефективністю, однак страждають від контекстної нечутливості. Статистичні методи (TF, TF-IDF, n-грам аналіз, LSA) дозволяють ефективно обробляти великі корпуси, але також не враховують глибокий контекст. Методи машинного навчання, особливо з використанням трансформерів, продемонстрували високу точність, але потребують значних ресурсів. Гібридні підходи, що комбінують кілька методів, стали логічним еволюційним етапом розвитку аналізу емоцій тексту.

Запропонований у роботі комбінований метод є прикладом гібридного підходу, в якому поєднуються два паралельні векторні представлення тексту: статистичне (TF-IDF) та контекстуальне (BERT). Таке поєднання дозволяє враховувати як частотні закономірності, так і глибокі семантичні залежності між словами. У поєднанні з ансамблевим класифікатором Random Forest вдалось побудувати стійку модель, здатну ефективно класифікувати короткі англійські тексти з високим рівнем точності.

Для оцінки ефективності запропонованого методу було проведено порівняння з базовими підходами – TF-IDF + RF та BERT + RF. Експерименти показали, що комбінована модель досягає точності класифікації до 89%, що перевищує результати альтернативних підходів (78% і 82% відповідно). Середній F1-score також виявився найвищим у комбінованій моделі – близько 88%. Такий результат підтверджує доцільність інтеграції різних типів ознак.

У ході роботи також було розглянуто часові витрати на тренування моделей. Комбінований метод очікувано виявився найбільш ресурсозатратним, що пов'язано з необхідністю одночасного обчислення двох типів векторів. Однак ці витрати повністю компенсуються зростанням точності та стабільності результатів. Було встановлено, що у задачах з високими вимогами до якості класифікації емоційного забарвлення, комбінований метод є більш доцільним вибором, ніж окремі складові підходи.

У результаті проведеного аналізу було сформульовано низку рекомендацій, що сприяють підвищенню точності емоційного аналізу текстів. Насамперед доцільно використовувати комбіновані векторні представлення, які об'єднують лексичні та контекстуальні ознаки, що дозволяє моделі краще розпізнавати як поверхневі, так і глибинні семантичні особливості. Обов'язковою умовою є якісна попередня обробка текстів: нормалізація, видалення стоп-слів, лематизація, що значно знижує рівень шуму у вхідних даних і підвищує узагальнюваність моделі. Також ефективним є використання сучасних трансформерних моделей, таких як BERT, навіть при роботі з короткими повідомленнями, оскільки вони здатні формувати вектори, які враховують контекст використання слів.

Важливим аспектом під час навчання моделі є збалансованість вибірки, що дозволяє уникнути перекосу результатів у бік одного класу. Для практичного впровадження комбінованого підходу варто оптимізувати

обчислювальні ресурси – зокрема, скорочувати кількість TF-IDF-ознак або застосовувати полегшені моделі, як-от DistilBERT.

Серед важливих висновків експериментального дослідження варто відзначити спостереження щодо найбільш типових помилок класифікації. Наприклад, сплутування нейтральних і позитивних повідомлень часто пов'язане з нечітко вираженою емоційністю або стилістично знеособленими фразами. Це свідчить про перспективність подальшого вдосконалення моделі через розширення набору ознак або впровадження attention-механізмів, здатних краще фокусуватися на релевантних частинах тексту.

Подальші дослідження можуть бути зосереджені на оптимізації архітектури моделі для скорочення часу її тренування, зокрема шляхом використання квантованих або дистильованих трансформерів. Крім того, гібридна архітектура може бути розширена на багатокласову класифікацію емоцій, що дозволить досягти більш детального аналізу психологічного стану автора повідомлення. Не менш важливою є розробка explainable AI-механізмів для пояснення прийнятих рішень, що особливо актуально у чутливих сферах, як-от медицина, освіта та правосуддя. Нарешті, запропоновану модель доцільно інтегрувати у вебсервіси, CRM-платформи, чат-боти та аналітичні системи соціальних мереж, що забезпечить її практичну реалізацію.

Таким чином, запропонований комбінований метод повністю виконав поставлену мету – забезпечення високоточного, гнучкого та інтерпретованого аналізу емоційної тональності текстів. Його універсальність, модульність і здатність до адаптації роблять цю модель ефективним інструментом як для наукових досліджень, так і для прикладних задач у сфері обробки природної мови.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Goldberg Y. *Neural Network Methods in Natural Language Processing*. 1st ed. San Rafael : Morgan & Claypool, 2017. 309 p.
2. Gupta B., Rawat A. Emotion recognition from text using transformer models. *Expert Systems with Applications*. 2023. Vol. 213. P. 119–149.
3. Acheampong F., Wenyu C., Nunoo-Mensah H. Text-based emotion detection: Advances, challenges, and opportunities. *Engineering Reports*. 2020. Vol. 2, №7. P. 1–24.
4. Bing L. *Sentiment Analysis: Mining Opinions, Sentiments, and Emotions*. 1st edition. Cambridge : Cambridge University Press, 2015, 383 p.
5. Bhattacharjee P., Nagwani N. A comprehensive review on sentiment analysis methods and approaches. *Cognitive Computation*. 2023. Vol. 15. P. 17–38.
6. Rani S., Kumar P. A sentiment analysis system to improve teaching and learning. *Computer Applications in Engineering Education*. 2021. Vol. 29, №2. P. 437–448.
7. Russell S., Norvig P. *Artificial Intelligence: A Modern Approach*. 4th ed. Boston : Pearson, 2020. 1136 p.
8. Dang N., Moreno-García M., De la Prieta F. Sentiment analysis based on deep learning: a comparative study. *Electronics*. 2020. Vol. 9, №3. P. 1–29.
9. Li J., Liu X., Liu H., Li X., Gao X. Sentiment analysis using recurrent neural networks with attention mechanism. *Neurocomputing*. 2021. Vol. 420. P. 221–231.
10. Jurafsky D., Martin J. *Speech and Language Processing*. 3rd ed. New Jersey : Pearson, 2020. 1024 p.
11. Sailunaz K., Alhajj R. Emotion and sentiment analysis from text: recent advances and future directions. *IEEE Access*. 2021. Vol. 9. P. 465–487.
12. Manning C., Schütze H. *Foundations of Statistical Natural Language Processing*. Cambridge : MIT Press, 1999. 680 p.

13. Minaee S., Kalchbrenner N., Cambria E. Deep learning based text classification: A comprehensive review. *ACM Computing Surveys*. 2022. Vol. 54, №3. P. 1–40.

14. Liang Y., Pan S., Zhou T. Attention-based neural networks for sentiment classification. *Knowledge-Based Systems*. 2020. Vol. 194. P. 15–28.

15. Ghafoor Y., Jinping S., Calderon F. TERMS: textual emotion recognition in multidimensional space. *The International Journal of Research on Intelligent Systems for Real Life Complex Problems*. 2023. P. 2673–2693.

16. Goodfellow I., Bengio Y., Courville A. Deep Learning. Cambridge : MIT Press, 2016. 775 p.

17. Howard J., Gugger S. Deep Learning for Coders with Fastai and PyTorch. Sebastopol : O'Reilly Media, 2020. 624 p.

18. Плутчик Р. Психоеволюційна теорія емоцій. Нью-Йорк : Harper & Row, 1980. 300 с.

19. Екман П. Теорія брехні. Київ : KM Publishing, 2012, 320 с.

20. Боков І.П., Петров К.Е. Дослідження методів аналізу емоційного забарвлення текстів // *Радіoeлектроніка та молодь у XXI столітті* : матеріали XXVIII Міжнар. молодіж. форуму, 16–18 квіт. 2025 р. Харків, 2025, Т. 6. С. 10–11.

21. Otter D., Medina J., Kalita J. A Survey of the Usages of Deep Learning for Natural Language Processing. *IEEE Transactions on Neural Networks and Learning Systems*. 2020. P. 604–624.

22. Zhang Y., Yang Q. An Overview of Multi-Task Learning for Natural Language Processing. *Transactions of the Association for Computational Linguistics*. 2021. P. 28.

23. Zhou J., Piao G., Breslin J. Deep Learning-Based Sentiment Analysis: A Comparative Review on Models, Datasets, and Metrics. *ACM Computing Surveys*. 2023. 40 p.

